平均利得基準をもつベクトル値マルコフ決定過程 : 多重連鎖の場合 (最適化の数理における離散と連続構造)

AUTHOR(S):

涌田, 和芳

CITATION:

涌田, 和芳. 平均利得基準をもつベクトル値マルコフ決定過程 : 多重連鎖の場合(最適化の数理における離散と連続構造). 数理解析研究所講究録 1996, 945: 199-203

ISSUE DATE:

1996-04

URL:

http://hdl.handle.net/2433/60209

数理解析研究所講究録
945巻 1996年 199-203

平均利得基準をもつベクトル値マルコフ決定過程 ：多重連鎖の場合

長岡工業高等専門学校　涌田和芳（Kazuyoshi WAKUTA）

1. はじめに

割引利得型ベクトル値マルコフ決定過程（VMDP）については多くの文献がある．一方，平均利得型VMDPの研究は少なく，十分には行はれていない：Thomas [7]は，Furukawa [3]の方法を修正し，完全エルゴーディックな場合に最適な確定的定常政策を求める政策反復法を与えた．Iki & Furukawa [4] は異なった最適性（bias optimality）のもとで，多重連鎖過程の場合の政策反復法について議論した．Durinovic et al.[2]は，多重連鎖の場合を多目的LP問題として定式化し，最適な確定的定常政策を特徴づけた．Novák [4] は，完全エルゴーディックな場合を多目的LP法を用いて解いた．

最近著者は，割引利得型および完全エルゴーディックな場合の平均利得型VMDPについて，最適な確定的定常政策を線形不等式系で特徴づけ，それに基づいた政策反復法を提案した[8][9][10]．本論の目的は，多重連鎖の場合の平均利得型VMDPについて同様なアプローチが可能であることを示すことである．

2. ベクトル値マルコフ決定過程

$a=(a_1,\ldots,a_m), b=(b_1,\ldots,b_m)\in R^m$ に対して

$a \underset{=}{\geq} b \Leftrightarrow a_k \underset{=}{\geq} b_k,\ k=1,\ldots,m$

$a \geqq b \Leftrightarrow a \underset{=}{\geq} b,\ a \neq b$

$a > b \Leftrightarrow a_k > b_k,\ k=1,\ldots,m.$

$U \subset R^m$に対して

$$e(U)=\{x\in U \mid x \underset{=}{\leq} y \text{ for some } y\in U \text{ implies } x=y\}.$$

ベクトル値マルコフ決定過程

$S=\{1,\ldots,N\}$ ：状態空間

A＝有限集合：行動空間，$A(i): i\in S$で実行可能な行動集合

$GrA=\{(i,a)\mid i\in S, a\in A(i)\}$

$p(j|i,a), i,j\in S, a\in A(i)$：推移確率

$r(i,a)=(r^1(i,a),\ldots,r^m(i,a))\in R^m$：利得関数

政策πの期待平均利得を$\phi_\pi(i_1)=(\phi_\pi^1(i_1),\ldots,\phi_\pi^m(i_1))$とする．ただし，

$$\phi_\pi^k(i_1)=\liminf_{T\to\infty}\frac{1}{T}\sum_{t=1}^{T}\sum_{j,a}P_\pi\{i_t=i,a_t=a\mid i_1\}r^k(j,a).$$

$$x_{ja}^T[\pi](i_1)=\frac{1}{T}\sum_{t=1}^{T}P_\pi\{i_t=j,a_t=a|i_1\},\ (j,a)\in Gr\,A$$

：T期までの状態ー行動の期待頻度

$X[\pi](i_1)$：$\{x^T[\pi](i_1),\ T=1,2,\ldots\}$の極限点$x[\pi](i_1)$の集合，とおく．このとき

$\phi_\pi(i_1) = (\phi_\pi^1(i_1),\ldots,\phi_\pi^m(i_1))$の各成分は,

$$\phi_\pi^k(i_1) = \liminf_{T\to\infty} \sum_{j,a} x_{ja}^T[\pi](i_1) r^k(j,a)$$

とかける.

Π: すべての政策の集合；$\pi = \{\pi_1,\pi_2,\ldots\}$, $\pi_n = \pi_n(\cdot|h_n)$

$\Pi_1(i_1)$：$X[\pi](i_1)$が一点だけからなる政策の集合

Π_D: すべての確定的定常政策の集合, $f: S \to A$ $s.t.$ $f(i) \in A(i)$

とおく.

政策$\pi \in \Pi_1(i_1)$に対しては, $\phi_\pi(i_1) = \sum_{j,a} x_{ja}[\pi](i_1) r(j,a)$である.

$$V(i_1) = \bigcup_{\pi\in\Pi} \phi_\pi(i_1),$$
$$V_1(i_1) = \bigcup_{\pi\in\Pi} \{\phi_\pi(i_1)\},\quad V_D(i_1) = \bigcup_{f^\infty\in\Pi_D} \{\phi_{f^\infty}(i_1)\},$$
$$W(i_1) = \bigcup_{\pi\in\Pi} \{\sum_{j,a} x_{ja}[\pi](i_1) r(j,a) \,|\, x[\pi](i_1) \in X[\pi](i_1)\}$$

とおく.

定義 2.1. すべての $i_1 \in S$ に対して$\phi_{\pi^*}(i_1) \in e(V(i_1))$であるとき, π^* は最適であるという.

命題 2.1. (Derman [1], Kallenberg [5]) $W(i_1) = V_1(i_1) = co\, V_D(i_1)$, $i_1 \in S$.

命題 2.2. $e(V(i_1)) = e(V_1(i_1))$, $i_1 \in S$.

3. 最適な確定的定常政策

$B^m(S)$をS上のm値関数の集合とし, $r^c(i_1,i_n,a_n) = < c(i_1), r(i_n,a_n) >$, $c \in B^m(S)$を利得関数にもつ非定常動的計画(NDP(c))を考える. そして, 政策πの期待平均利得を

$$J_\pi(i_1) = \sum_{j,a} x_{ja}[\pi](i_1) r^c(i_1,j,a),\ \pi \in \Pi_1(i_1),\ i_1 \in S$$

とする.

定義 3.1. 各 $i_1 \in S$ に対して, $J_{\pi^*}(i_1) \geqq J_\pi(i_1)$, $\pi \in \Pi_1(i_1)$であるとき, π^* はNDP(c)で最適であるという.

命題 3.1 (Yu[11]) 政策$\pi^* \in \bigcap_{i_1\in S} \Pi_1(i_1)$が最適ならば, ある$c \in B^m(S)$, $c > 0$に対してπ^*はNDP(c)で最適であり, 逆も成り立つ.

$S(\pi,i_1) = \{j \in S | P_\pi\{i_t = j | i_1\} > 0 \text{ for some } t \geqq 1\}$, $\pi \in \Pi_1(i_1), i_1 \in S$,
$S(i_1) = \bigcup_{\pi\in\Pi_1(i_1)} S(\pi,i_1), i_1 \in S$とおく.

定理 3.1. f^{∞}が最適ならば，各$i_1 \in S$について，任意の$(i_t,a_t) \in Gr\,A$，$i_t \in S(f^{\infty},i_1)$に対して

$$< c(i_1),\phi_{f^{\infty}}(i_t) > \geqq \sum_{j=1}^{N} p(j|i_t,a_t) < c(i_1),\phi_{f^{\infty}}(j) > \tag{3.1}$$

$$< c(i_1),\phi_{f^{\infty}}(i_t) > + < c(i_1),u(i_t) > \geqq < c(i_1),r(i_t,a_t) > + \sum_{j=1}^{N} p(j|i_t,a_t) < c(i_1),u(j) > \tag{3.2}$$

なる$u \in B^m(S)$と$c \in B^m(S)$, $c > 0$が存在する．

定理 3.2. 各$i_1 \in S$について，任意の$(i_t,a_t) \in Gr\,A$，$i_t \in S(f^{\infty},i_1)$に対して，(3.1) (3.2)が成り立てば，$f^{\infty}$は最適である．

系 3.1. 各$i_1 \in S$について，任意の$(i_t,a_t) \in Gr\,A$に対して，(3.1) (3.2)が成り立てば，f^{∞}は最適である．

4. 線形不等式系による最適性の特徴付け

$i_1 \in S$を固定し，$x_k = c^k(i_1)$, $k = 1,2,\ldots,m$，とおき，(i_t,a_t)を(i,a)で置き換えると定理 3.1の条件は，次のようになる．

$$(S_{i_1}):\begin{cases} \sum_{k=1}^{m} \phi_{f^{\infty}}^{k}(i)x_k \geqq \sum_{k=1}^{m}\sum_{j=1}^{N} p(j|i,a)\phi_{f^{\infty}}^{k}(j)x_k \\ \sum_{k=1}^{m} \phi_{f^{\infty}}^{k}(i)x_k + \sum_{k=1}^{m} u^k(i)x_k \geqq \sum_{k=1}^{m} r^k(i,a)x_k + \sum_{k=1}^{m}\sum_{j=1}^{N} p(j|i,a)u^k(j)x_k, \\ \qquad\qquad (i,a) \in Gr\ A,\ i \in S(f^{\infty},i_1) \\ x_k > 0,\ k = 1,\ldots,m. \end{cases}$$

定理 4.1. f^{∞}が最適ならば，各線形不等式系$(S_1),\ldots,(S_N)$は解をもつ．

定理 4.2. 各線形不等式系$(T_1),\ldots,(T_N)$が解をもてば，f^{∞}は最適である．ただし，$(T_1),\ldots,(T_N)$は，定理3.2に対応する線形不等式系である．

系 4.1. 各線形不等式系$(U_1),\ldots,(U_N)$が解をもてば，f^{∞}は最適である．ただし，$(U_1),\ldots,(U_N)$は，系3.1に対応する線形不等式系である．

次のＬＰ問題を考える．

$P(S_{i_1})$: *Max* z

subject to

$$\begin{cases} x_1 \geqq z, \ldots, x_m \geqq z \\ \sum_{k=1}^{m} \phi^k_{f^\infty}(i) x_k \geqq \sum_{k=1}^{m} \sum_{j=1}^{N} p(j|i,a) \phi^k_{f^\infty}(j) x_k \\ \sum_{k=1}^{m} \phi^k_{f^\infty}(i) x_k + \sum_{k=1}^{m} u^k(i) x_k \geqq \sum_{k=1}^{m} r^k(i,a) x_k + \sum_{k=1}^{m} \sum_{j=1}^{N} p(j|i,a) u^k(j) x_k, \\ \qquad\qquad (i,a) \in Gr\ A, i \in S(f^\infty, i_1) \\ x_k \geqq 0, k = 1, \ldots, m, z \geqq 0. \end{cases}$$

定理 4.3.

(i) $P(S_{i_1})$の最大値が正のとき，またその時に限り(S_{i_1})は解を持つ．このとき，$P(S_{i_1})$は非有界である．

(ii) $P(S_{i_1})$の最大値が0のとき，またその時に限り(S_{i_1})は解を持たない．

$P(T_{i_1})$，$P(U_{i_1})$についても同様な定理が成り立つ．

5. 数値例

$S = \{1,2\}$, $A = A(1) = A(2) = \{1,2\}$

$p(1|1,1) = 1$, $p(2|1,1) = 0$

$p(1|1,2) = 0$, $p(2|1,2) = 1$

$p(1|2,1) = 0$, $p(2|2,1) = 1$

$p(1|2,2) = 1$, $p(2|2,2) = 0$

$r(1,1) = (0,0)$, $r(1,2) = (1,-1)$

$r(2,1) = (1,2)$, $r(2,2) = (2,1)$.

α: $\alpha(1) = 1$, $\alpha(2) = 1$; β: $\beta(1) = 1$, $\beta(2) = 2$

γ: $\gamma(1) = 2$, $\gamma(2) = 1$; δ: $\delta(1) = 2$, $\delta(2) = 2$

［ γの最適性の判定 ］

$$\phi_\gamma = \begin{bmatrix} 1 & 2 \\ 1 & 2 \end{bmatrix}, \quad u_\gamma = \begin{bmatrix} 0 & -3 \\ 0 & 0 \end{bmatrix}$$

- $i=1$, $a=1$のとき
  $x_1 + 2x_2 \geqq x_1 + 2x_2$
  $x_1 + 2x_2 - 3x_2 \geqq -3x_2$

- $i=1$, $a=2$のとき
  $x_1 + 2x_2 \geqq x_1 + 2x_2$
  $x_1 + 2x_2 - 3x_2 \geqq x_1 - x_2$

- $i=2,\ a=1$のとき
  $x_1+2x_2 \geqq x_1+2x_2$
  $x_1+2x_2 \geqq 2x_1+x_2-3x_2$
- $i=2,\ a=2$のとき
  $x_1+2x_2 \geqq x_1+2x_2$
  $x_1+2x_2 \geqq x_1+2x_2$

$P(S_0)$: $Max\ z$

$subject\ to$

$$\begin{cases} x_1 \geqq z,\ x_2 \geqq z \\ -x_1-2x_2 \leqq 0 \\ x_1-4x_2 \leqq 0 \\ x_1 \geqq 0,\ x_2 \geqq 0,\ z \geqq 0. \end{cases}$$

これを解いて$Max\ z=\infty$. すなわちγは最適である.

参考文献

[1] C. Derman, Finite State Markovian Decision Processes (Academic Press, New York,1970).

[2] S. Durinovic, H. M. Lee, M. N. Katehakis, and J. A.Filar,Multiobjective Markov decision process with average reward criterion, Large Scale Systems 10 (1986) 215-226.

[3] N. Furukawa, Vector-valued Markovian decision processes with countable state space, in: R. Hartley, L. C. Thomas, and D. J. White, eds., Recent Developments in Markov Decision Processes (Academic Press, New York, 1980) pp.205-223.

[4] T. Iki and N. Furukawa, Vector-valued Markov decision processes with average criterion, Mem. Fac. Edu. Miyazaki Univ. Nat. Sci. 54-55 (1984) 1-10.

[5] L. C. M. Kallenberg, Linear Programming and Finite Markovian Control Problems (Mathematisch Centrum, Amsterdam, 1983).

[6] J. Novák, Linear programming in vector criterion Markov and semi-Markov decision processes, Optimization 20 (1989) 651-670.

[7] L. C. Thomas, Constrained Markov decision processes as multi-objective problems, in: S. French, R. Hartley, L. C. Thomas, and D. J. White, eds., Multi-Objective Decision Making (Academic Press, New York, 1983) pp. 77-94.

[8] K. Wakuta, Vector-valued Markov decision processes and the systems of linear inequalities, Stochastic Process. Appl. 56(1995) 159-169.

[9] K. Wakuta and K.Togawa, A solution procedure for multiobjective Markov decision processes, Preprint.

[10] K. Wakuta and K. Togawa, A solution procedure for multiobjective Markov decision processes : Average reward case, Preprint.

[11] P. L. Yu, Multiple-Criteria Decision Making (Plenum Press, New York, 1985).